

DOI:10.19651/j.cnki.emt.1802414

改进深度置信网络对 TE 过程故障诊断研究

程焕新 王建庆

(青岛科技大学自动化与电子工程学院 青岛 266061)

摘要: 为了实现对 TE 过程的故障诊断,改进了深度置信网络(DBN)的故障诊断方法。传统 DBN 在训练过程有冗余特性,减弱网络的特征提取能力,改进 DBN 在无监督学习阶段的似然函数中加入惩罚正则项,通过稀疏约束得到 DBN 训练集的稀疏分布,再用 Laplace 函数的分布引导 DBN 节点的稀疏状态,用 Laplace 函数中的位置参数控制稀疏的力度,使无标签的数据特征更加直观的表示出来,最后将改进 DBN 和传统 DBN、BP 神经网络的仿真实验结果进行对比。实验结果,证明改进的 DBN 在故障诊断方面优于传统 DBN 和 BP 神经网络,达到了最好的诊断准确度,具有很高的理论研究价值。

关键词: TE 过程;故障诊断;深度置信网络;惩罚正则项;拉普拉斯函数

中图分类号: TP277;TN98 **文献标识码:** A **国家标准学科分类代码:** 510

Improved DBN for TE process fault diagnosis

Cheng Huanxin Wang Jianqing

(College of Automation Engineer, Qingdao University of Science & Technology, Qingdao 266061, China)

Abstract: In order to realize the fault diagnosis of the tennessee eastman (TE) process, the fault diagnosis method of the deep belief network (DBN) is improved. The traditional DBN will generate redundant features in the training process, weaken the feature extraction ability of the network, improve the DBN to add the penalty regular term in the likelihood function of the unsupervised learning phase, obtain the sparse distribution of the DBN training set through the sparse constraint, and then use the Laplace function. The distribution guides the sparse state of the DBN node, and uses the positional parameters in the Laplace function to control the sparse strength, so that the unlabeled data features can be more intuitively represented. Finally, the improved DBN and traditional DBN and BP neural network simulation results are compared. The experimental results show that the improved DBN is superior to the traditional DBN and BP neural network in fault diagnosis, achieving the best diagnostic accuracy and high Theoretical research value.

Keywords: tennessee eastman (TE) process; fault diagnosis; deep belief networks (DBN); Punish regular item; Laplace function

0 引言

当今社会的迅速发展,孕育出了规模化、复杂化、高速化和智能化的现代工业体系^[1]。现代工业的运行工况和设备结构错综复杂,在提高企业效率的同时,发生故障的概率也跟着增大,即使系统微小的故障,也有可能引起整个生产过程的瘫痪,严重的故障甚至危机人们的生命安全^[2]。

深度置信网络(DBN)以其优异的特征提取和训练算法^[3],已经化工过程故障诊断领域实现广泛应用,并取得了良好的成果^[4]。当前,Hinton 提出了交叉熵稀疏惩罚因子,增加隐藏单元的稀疏性;之后 Lee 等^[5]提出将误差平方和与稀疏受限玻尔兹曼机(RBM)结合,来惩罚平均激活偏

离给定固定水平的隐单元;Chen 等^[6]通过在网络中加入流行的局部性来保留对 DBN 隐藏层的约束,来获得模型的稀疏和区分性表示。但以上的方法都需要预先给定“稀疏目标”,基于这一问题,提出改进深度置信网络模型,并和传统 DBN、BP 神经网络分别,对 TE 过程的数据样本进行仿真实验,得到不同故障类型诊断的准确度,实验结果证明改进 DBN 在故障诊断方面更有优势。

本次化工过程的故障诊断以 TE 过程为研究对象展开。TE 过程是源自真实化工流程^[7]、用于评估过程控制和监测方法的工业过程仿真。在化工过程领域的研究中,TE 过程能够真实有效的模拟现场复杂多变的化工过程的许多典型特征^[8],目前该过程被广泛作为化工过程操控、改良、

监控与故障诊断的研究对象^[9]。

1 深度置信网络

深度置信网络是一种深度学习算法^[10]，其网络结构主要包含两部分：堆叠限制玻尔兹曼机^[11]的无监督预训练和有监督的分类或回归学习。DBN 在训练模型的过程中主要分为无监督预训练 RBM 与有监督向后微调^[12]。

1.1 预训练阶段

对 RBM 进行贪婪无监督算法逐层训练，高层 RBM 以底层 RBM 的输出表征作为训练样本，逐层重复，堆叠成深度置信网络^[13]。

1.2 向后微调

向后微调是指以最后一层 RBM 的输出作为网络下一层的训练样本，然后对模型分类器进行有监督的训练^[14]。由于 RBM 网络各个层的权值特征向量最优映射仅局限于各个层内，并不能扩展至整个 DBN 网络，所以通过监督学习网络将标签信息自顶向下学习至每一层 RBM，从而微调整个网络，使权值特征向量最优映射扩展至整个 DBN 网络^[15]。

2 改进的深度置信网络模型

传统的 DBN 在训练过程容易产生大量的冗余特性，影响特征提取能力。众多研究论文和专题研讨会表明，稀疏表示可以用来解释数据特征，因此，在 DBN 的无监督学习阶段的似然函数中加入惩罚正则项，可以直观地表示数据特征。

假设给一个训练集 $\{v(1), v(2), v(3), \dots, v(m)\}$ ，然后将稀疏正则化加入到无监督学习阶段，优化之后的模型定义如下：

$$F = F_{\text{unsup}} + \lambda F_{\text{sparse}} \quad (1)$$

式中： F_{unsup} 是 RBM 无监督学习阶段的似然函数； λ 是惩罚正则化参数，表示了无监督学习阶段数据分布相对于惩罚正则化项的重要性； F_{sparse} 是稀疏正则化函数。

RBM 引入稀疏正则化后建立故障诊断模型，其目标函数如下：

$$\text{maximize} \{W_{ij}, a_i, b_j\}^F = \text{maximize} \{W_{ij}, a_i, b_j\}^{(\frac{1}{n} \sum_{i=1}^n \ln P(v^{(i)}) + \lambda F_{\text{sparse}})} \quad (2)$$

在此基础上，再引入 Laplace 函数，构建 Laplace 函数稀疏受限玻尔兹曼机(Laplace sparse RBM, LS-RBM)。

$$F_{\text{sparse}} = \sum_{i=1}^m L(q_i, p, u) \quad (3)$$

$$L(q_i, p, u) = \frac{1}{2b} e^{-\frac{|u-a|}{b}} \quad (4)$$

式中： $L(q_i, p, u)$ 为 Laplace 函数； q_i 是数据中第 i 个隐藏单元的条件期望的平均值； p 表示 m 个隐藏单元 h_i 的稀疏度； u 是 Laplace 函数的位置参数，可以用它来控制稀疏的力度。

$$q_j = \frac{1}{m} \sum_{i=1}^m E[h_j^{(i)} | v^{(i)}] \quad (5)$$

式中： $E(h_i^{(i)} | v^{(i)})$ 是训练数据的第 i 个隐藏单元的期望； h_i 的值只可取 0 或 1，当 h_i 取 1 时有式(6)。

$$q_j = \frac{1}{m} \sum_{i=1}^m P[h_j^{(i)} = 1 | v^{(i)}] = \frac{1}{m} \sum_{i=1}^m q_j^{(i)} \quad (6)$$

最后，训练 LS-RBM 额目标函数如下：

$$\text{maximize} \{W_{ij}, a_i, b_j\}^{(\frac{1}{n} \sum_{i=1}^n \ln P(v^{(i)}) + \lambda (\sum_{i=1}^m \frac{1}{2b} e^{-\frac{|u-a|}{b}}))} \quad (7)$$

式(7)有两部分，第 1 部分是对数似然函数，第 2 部分是引进的 Laplace 函数稀疏正则项。

接下来用 Hinton 提出的对比散度算法对似然函数进行参数更新，这样可以有效减少数据训练的耗费时间。就下来再使用梯度下降法求解模型函数的最优解。

$$\frac{\partial F}{\partial W_{ij}} = \frac{\partial}{\partial W_{ij}} \left(\frac{1}{n} \sum_{i=1}^n \ln P(v^{(i)}) + \frac{\partial F_{\text{sparse}}}{\partial W_{ij}} \right) \quad (8)$$

$$\frac{\partial F}{\partial b_j} = \frac{\partial}{\partial b_j} \left(\frac{1}{n} \sum_{i=1}^n \ln P(v^{(i)}) + \frac{\partial F_{\text{sparse}}}{\partial b_j} \right) \quad (9)$$

$$\frac{\partial F}{\partial a_i} = \frac{\partial}{\partial a_i} \left(\frac{1}{n} \sum_{i=1}^n \ln P(v^{(i)}) \right) \quad (10)$$

最后将梯度下降求导后的值代入参数更新式中，得到新的求解值：

$$W: = mW + \alpha (P(h_1 = 1 | v_1) v_1^T - P(h_2 = 1 | v_2) v_2^T) + \frac{\lambda}{m} \left(\sum_{j=1}^m \frac{\partial(L(q_j, u, b))}{\partial q_i} \right) \left(\sum_{i=1}^m q_i^t (1 - q_i^t) v_i^{(i)} \right) \quad (11)$$

$$a: = ma + \alpha (v_1 - v_2) \quad (12)$$

$$b: = mb + \alpha (P(h_1 = 1 | v_1) - P(h_2 = 1 | v_2)) + \frac{\lambda}{m} \left(\sum_{i=1}^m \frac{\partial(L(q_i, p, u))}{\partial q_i} \right) \left(\sum_{i=1}^m q_i^t (1 - q_i^t) \right) \quad (13)$$

当 $q_i < p$ 时：

$$\frac{\partial(L(q_i, p, u))}{\partial q_i} = \left(\frac{1}{2u} e^{-\frac{(u-\sum v_i)}{u}} \right) \left(\frac{1}{u} \right) \quad (14)$$

当 $q_i \geq p$ 时：

$$\frac{\partial(L(q_i, p, u))}{\partial q_i} = \left(\frac{1}{2u} e^{-\frac{(\sum v_i - u)}{u}} \right) \left(-\frac{1}{u} \right) \quad (15)$$

将引入拉普拉斯函数更新后的参数值训练网络，构建改进 RBM 模型，用改进的 RBN 模型生成改进 DBN 模型。

3 仿真实验过程及结果

3.1 TE 过程的故障类型

TE 过程中预先设定了 15 个是已知故障故障类型，如表 1 所示。

3.2 TE 过程故障样本说明

数据分为训练数据和测试数据两部分，其中训练数据仿真 25 h，测试数据仿真 48 h。两组数据均为每 3 min 采样一次。数据仿真如图 1、2 所示。

3.3 基于 BP 的故障诊断的仿真实验研究

以 52 个变量为网络的输入层建立 BP 神经网络，确定

表1 TE过程故障类型

故障序号	检测准确度	故障序号
IDV(1)	A/C 进料比率变化, B 成分不变(流 4)	阶跃
IDV(2)	B 成分变化, A/C 进料比率不变(流 4)	阶跃
IDV(3)	D 的进料温度变化(流 2)	阶跃
IDV(4)	反应器冷却水的入口温度变化	阶跃
IDV(5)	冷凝器冷却水的入口温度变化	阶跃
IDV(6)	A 进料损失(流 1)	阶跃
IDV(7)	C 压力损失(流 4)	阶跃
IDV(8)	A、B、C 进料成分变化(流 4)	随机变量
IDV(9)	D 的进料温度变化(流 2)	随机变量
IDV(10)	C 的进料温度变化(流 2)	随机变量
IDV(11)	反应器冷却水的入口温度变化	随机变量
IDV(12)	冷凝器冷却水的入口温度变化	随机变量
IDV(13)	反应动态变化	慢偏移
IDV(14)	反应器冷却水阀门	粘住
IDV(15)	冷凝器冷却水阀门	粘住

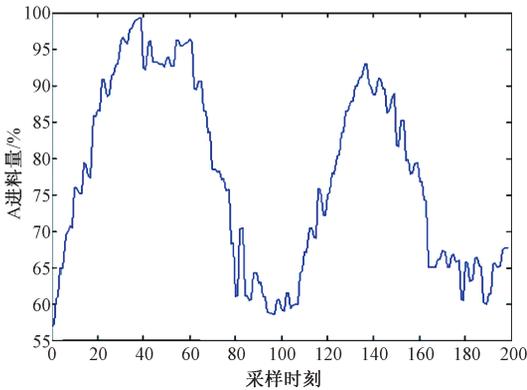


图1 故障 A 进料量数据

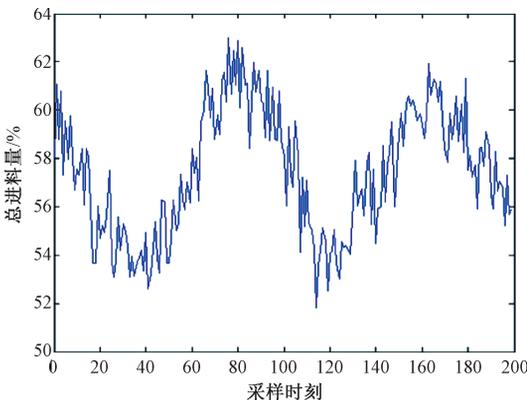


图2 故障总进料量数据

已知故障 1~15 的序号指示:例如判断为故障 3 则将数组第 4 位置 1,判断无事故则各位置 0;实际输出结果中,置 1 项与置 0 项分别为接近 1 与接近 0 的小数,程序返回值为数组中最大值的序位来判断故障序号。训练样本为正常工况及各类故障工况各 80 组,共计 1 280 组,采用自适应学习速率动量下降 BP 算法进行训练,迭代次数 1 500,学习率 0.486,动量因子为 0.45。训练样本为正常工况及各类故障工况各 20 组,共计 320 组。

3.4 基于 DBN 的故障诊断的仿真实验研究

以 52 个变量为网络的输入层建立深度置信网络,确定网络的结构为 52→180→300→16;为使数据适应网络要求,通过预处理将数据等比例缩放至[0,1]区间;输出层为一组形如[0 1 0 0 0 0 0 0 0 0 0 0 0 0 0]的 16 维数组,其中 1~16 位表示对已知故障 1~15 的序号指示:例如工况为故障 3 则将数组第 4 位置 1,判断无事故则各位置 0;实际输出结果中,置 1 项与置 0 项分别为接近 1 与接近 0 的小数,程序返回值为数组中最大值的序位来判断故障序号。训练样本为正常工况及各类故障工况各 80 组,共计 1 280 组,三层 RBM 的迭代次数均为 100 组,学习率 0.1;输出层采用 Softmax 回归配合常规 BP 算法进行监督训练,迭代次数 1 600,学习率 0.6。训练样本为正常工况及各类故障工况各 20 组,共计 320 组。

3.5 仿真实验结果对比

通过上述实验过程,然后将三者的仿真实验结果整合到表 2 作对比。

表2 故障诊断仿真实验结果对比表 (%)

故障序号	BP 神经网络 检测准确度	传统 DBN 检测准确度	改进 DBN 检测准确度
IDV(1)	97	99	99
IDV(2)	95	98	98
IDV(3)	98	98	97
IDV(4)	95	96	99
IDV(5)	92	97	98
IDV(6)	94	96	99
IDV(7)	97	97	100
IDV(8)	23	96	99
IDV(9)	10	95	98
IDV(10)	46	97	98
IDV(11)	37	97	99
IDV(12)	40	96	100
IDV(13)	34	95	99
IDV(14)	81	97	98
IDV(15)	76	96	99

网络的结构 52→80→200→16;输出层为一组形如[0 1 0 0 0 0 0 0 0 0 0 0 0 0 0]的 16 维数组,其中 1~16 位表示对

从表 2 中 TE 过程的故障诊断仿真实验结果对比,可以清楚地看到 BP 神经网络对由阶跃引发的故障诊断效果

较好,但对由随机变量、慢偏移及粘住引起的故障诊断效果不理想,准确率偏低,无法准确地判断出这些故障。DBN 对由阶跃、随机变量、慢偏移及粘住引起的故障诊断准确率都很高。相较 BP 神经网络有了大幅度提升,尤其对于 BP 神经网络诊断效果不佳的后三类故障,表现出了良好的诊断性能。改进的 DBN 有在传统 DBN 基础上引入惩罚正则项,进一步加强了模型的辨别能力,整体故障诊断准确度比传统 DBN 又有所提高,准确度都能达到 98% 以上,满足我们的预期效果。

4 结 论

良好的过程工业故障诊断与其安全稳定生产休戚相关,本文为了更好的实现对 TE 过程的故障诊断,在 DBN 无监督学习阶段的似然函数中引入惩罚正则项,通过稀疏约束获得训练集的稀疏分布,将无标签的数据特征直观地表示出来。然后将 BP 神经网络、传统 DBN 和改进 DBN 三者进行故障诊断的仿真实验,并对他们 3 个的仿真实验结果进行对比。证明改进的 DBN 在准确度上优于传统 DBN 和 BP 神经网络,故障诊断都能达到 98% 以上,可以应用于实际生产,有很高的应用价值。

在此基础上,提出了一种基于改进 DBN 的故障诊断方法。该方法以 TE 流程为例,做仿真实验验证了其有效性。诊断结果的准确度与应用广泛的 BP 网络、传统 DBN 相比较,显著优于这两者,是一种可行而有效的故障诊断方法,工程应用前景广阔。

参考文献

- [1] DOWN J J, VOGEL E F. A plant wide industrial process control problem[J]. Computers & Chemical Engineering, 1993, 17(3): 245-255.
- [2] 周培建. 化工过程异常事件智能诊断研究[D]. 北京: 北京化工大学, 2008.
- [3] 任浩, 屈剑锋, 柴毅. 深度学习在故障诊断领域中的研究现状与挑战[J]. 控制与决策, 2017, 32(8): 1345-1358.
- [4] 葛强强. 基于深度置信网络的数据驱动故障诊断方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2016.
- [5] LEE H, EKANADHAM C, NG A Y. Sparse deep belief net model for visual area V2 [C]. 20th International Conference on Neural Information Processing Systems, 2007: 873-880.
- [6] CHEN D, LV J, YI Z. Graph regularized restricted Boltzmann machin.[J]. IEEE Transactions on Neural Networks & Learning Systems, 2018, 29(6): 2651-2659.
- [7] 王新明. 基于 TE 的化工过程故障诊断算法研究[D]. 兰州: 兰州理工大学, 2010.
- [8] CHANDRA B, SHARMA R K. Fast Learning in deep neural networks[J]. Neurocomputing, 2015, 171(C): 1205-1215.
- [9] 张姮. TE 过程故障诊断方法比较研究[D]. 沈阳: 沈阳理工大学, 2014.
- [10] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [11] 梅恒荣, 殷礼胜, 刘冬梅, 等. 改进粒子群算法优化的 SVM 模拟电路故障诊断[J]. 电子测量与仪器学报, 2017, 31(8): 1239-1246.
- [12] HINTON G E. Training products of experts by minimizing contrastive divergence [J]. Neural computation, 2002, 14(8): 1771-1800.
- [13] 张奎, 王建南, 王肖峰. 基于神经网络的变压器故障诊断[J]. 电子测量技术, 2017, 40(12): 98-101.
- [14] 刘梦溪, 王征. 基于稀疏深度置信网络的图像分类识别研究[J]. 微电子学与计算机, 2018, 35(9): 59-63.
- [15] OLSHAUSEN B A. Emergence of simple-cell receptive field properties by learning a sparse code for natural images[J]. Nature, 1996, 381(6583): 607-609.

作者简介

程焕新, 博士, 教授, 硕士生导师, 主要研究方向为控制理论与应用。

王建庆(通信作者), 硕士研究生, 主要研究方向为控制理论与应用。

E-mail: 302801448@qq.com